基于内容的生成式图书协同推荐方法研究*

程川生[1] 辛鑫[2] 王一丹[2] 李小洁[1]

1. 山东大学图书馆 济南 250101

2. 山东大学计算机科学与技术学院 青岛 266000

摘要：[目的]通过生成式图书推荐方法，减轻图书资源信息过载问题，丰富读者在线体验。[应用背景] 应用于山东大学图书馆图书推荐服务，涵盖 2017 年后采购的部分图书信息 111479 条，相关读者信息 31840 条，借阅记录 390300 条。[方法] 对于借阅次数＞1 图书推荐，采用协同信息与内容特征信息融合增强的生成式推荐算法。对于借阅次数≤1 的图书推荐，采用基于预训练语言模型的内容推荐方法，解决冷启动问题。[结果] 实验结果表明，对于借阅次数超过 1 图书来说，相较于 LightGCN 算法，本文所提出的方法 Recall@100 提升达到了 18.9%，NDCG@100 提升达到了 16.8%；对于不存在借阅历史的图书来说，相较于 LightGCN 算法，本文所提出的方法 Recall@100 达到了 0.3053，NDCG@100 达到了 0.088；对于借阅次数不超过 1 的图书来说，相较于 LightGCN 算法，本文所提出的方法在 Recall@100 达到了 0.0145，NDCG@100 提升了 132%。[结论] 统一内容特征及协同信息的生成式图书推荐方法性能优越，能够在减轻信息过载、丰富读者在线体验方面发挥重要作用。

关键词：图书推荐　　生成式模型　　协同过滤

分类号：G252

“每个读者有其书”、“每本书有其读者”是图书馆学五定律的重要论述。如何精准地满足读者个性化需求，以实现高效知识传播，并为图书匹配最为合适的受众群体，一直是众多学者持续关注的重要课题。近年来，随着图书馆印本资源的持续增长和电子资源的日益丰富，促使这一问题显得尤为突出和紧迫。

然而，图书是一种具有主观性和情感性的产品，读者对图书的喜好因人而异，难以通过简单的内容匹配实现有效推荐。众多学者通过持续性研究与实践，积极探索更加优质、高效以及个性化的图书推荐服务。生成式人工智能作为新兴的机器学习技术，在众多领域展现出了巨大的潜力，其带来的“人-机”关系同样可以从馆藏资源推广、阅读活动、读者发展等方面对图书馆阅读推广产生变革[1]。但生成模型在图书推荐领域的实践探索却相对较少。因此，本文提出了统一内容特征及协同信息的生成式图书推荐方法框架，为满足读者个性化、多样化的信息需求提供服务。

* 本文系山东大学教育教学改革研究重点项目“数智时代未来学习生态建设”（项目编号：2023Z21）研究成果之一。

作者简介：程川生，图书馆副馆长，副研究馆员，硕士研究生；辛鑫，讲师，博士；王一丹，在读研究生；李小洁，网络信息技术中心主任，馆员，硕士研究生，lixiaojie@sdu.edu.cn，通讯作者。

1 研究现状/research status

1.1 图书推荐系统

近二十年，图书推荐系统作为解决信息过载问题的重要手段，受到了学术界和工业界的广泛关注与深入研究。

从推荐方法来看，协同过滤推荐、基于内容的推荐和混合推荐应用最为广泛。其中，基于近邻思想或基于模型的协同过滤算法是最为主流的推荐方法。其次是基于内容特征推荐相似图书的推荐方法，以及将多种推荐方法相结合的混合推荐系统。而其他诸如基于关联规则、基于知识的推荐方法也在不断尝试应用。

从数据特征来看，相关研究综合考量了图书特征、读者信息以及交互行为，以丰富推荐系统的信息维度。读者方面，不同研究中分别探讨了网络社区用户[2]、OPAC 未登录用户[3]、馆外用户[4]、儿童[5]等特殊读者群体的个性化图书推荐场景，并融合读者的自然属性、兴趣属性、社交属性、微观行为序列[6]等构建用户画像[7]。图书方面，在采集题目、关键词、作者、出版社等内容特征之外，相关研究还考量了图书目录信息[8]、评分信息[9]、评论信息[10]、畅销书效应[11]等。交互信息方面，历史借阅记录是最为核心的交互数据，而订阅记录[12]、共借关系[13]，以及包括收藏、分享、点击等行为在内的隐式反馈数据[14]，同样被纳入研究范畴。

从系统性能来看，在不同研究成果中，数据集规模、稀疏程度、实时性要求等常见问题均得到了针对性优化处理。如陈玲洪[15]等提出将知识图谱和读者画像技术融合于图书检索，从而有效改善数据稀疏和冷启动问题。刘园园[16]设计了基于读者兴趣挖掘的深度学习推荐模型以改善传统推荐算法泛化能力不强问题。

1.2 生成式推荐系统

传统图书推荐算法多基于判别式思想，通过不断优化正采样和负采样的判别边界，从而完成模型训练。然而，判别式推荐框架难以确保实验数据中负样本的真实性和代表性，并且其判别过程仅限于已知的候选物品集合，这种限制极大地束缚了系统对用户兴趣的探索和捕捉，因此判别式推荐存在难以规避的固有限制[17]。

近年来，人工智能生成内容（AI-Generated Content, AIGC）已在多领域取得了显著成就，在信息推荐领域同样展现了其突破传统推荐范式局限性的巨大潜力[18]。生成式模型通过学习数据分布，生成与真实数据分布相似的新数据，以提供更精准的推荐，有效满足用户多样化的信息需求。在个性化推荐中常见的生成式模型有生成对抗网络(GAN)[19]或变分自编码器(VAE)[20]，随着技术不断发展，基于大语言模型[21]、扩散模型[22]、多任务学习[23]的生成式推荐算法不断涌现。这些算法各有特点，适用于不同的场景和数据集。通过生成个性化、创新性、主动性推荐结果，更好满足用户多样化需求。

虽然生成式推荐系统的相关研究正在不断深入，但仍面临着一些挑战和问题。如数据稀疏性和冷启动问题、计算复杂性和可扩展性、推荐结果的可解释性等。数据稀疏性指的是读者与大量图书间的借阅数据有限，导致模型难以准确捕捉读者偏好。冷启动问题则涉及新读者或新图书在推荐系统中缺乏足够历史数据，难以进行有效推荐。针对这些问题，现有研究提出了多种解决方案。例如，利用知识图谱结合特征学习[24]，通过挖掘读者与读者间的潜

在关系，解决数据稀疏性问题，并提升推荐决策的准确性和多样性。在计算复杂性和可扩展性方面，研究者们通过优化模型结构和算法设计，如采用高效的注意力机制和降采样技术，降低计算成本，提升模型处理大规模数据的能力。对于推荐结果的可解释性，可探索基于知识图谱推理和自然语言生成的方法，生成流畅、个性化的推荐理由，提升读者体验。

1.3 小结

综上所述，图书推荐系统立足计算机领域经典推荐方法，通过深入挖掘用户的历史行为、兴趣偏好以及图书的内容特征等信息，融合知识图谱[25]、深度学习[26]、神经网络[27]等新兴技术，从而推陈出新，不断优化和改进算法性能。AIGC 的显著成果和潜力同样为下一代推荐系统发展带来了革新性的解决方案。因此，借助生成式模型建模图书-读者之间的交互关系，观测读者行为数据的潜在生成分布，有助于启发传统图书推荐系统，为实现生成式图书推荐新范式产生积极作用。不过，从现有研究来看，基于生成式模型的图书推荐研究还较为有限，如何在生成式模型中有效融合图书特征信息和用户历史交互信息更是一个亟待深入研究的学术问题，因此，本研究从生成式推荐角度进行图书推荐系统的分析和探讨。

2 统一内容特征及协同信息的生成式图书推荐方法框架/A Generative Book Recommendation Method Framework with Unified Content Features and Collaborative Information

本文提出了统一内容特征及协同信息的生成式图书推荐方法框架。本文主要面临两个推荐场景。场景一是对有图书借阅记录的图书（借阅记录超过 1）进行智能推荐，采用协同与内容信息融合增强的生成式推荐算法。该场景包括读者-图书推荐和图书-图书索引两个任务。其中输入为与读者交互过图书的相关数据，包括读者和图书借阅行为数据和图书文本描述的内容数据，输出为所推荐图书。图书的文本描述被输入到语言模型中，来封装内容信息。所用的 MT5 模型保留了 Transformer 结构编码器-解码器架构。场景二主要面向刚入库的新图书（借阅记录不超过 1），实验中所用数据分为两类，分别对借阅记录为 0 和借阅记录不超过 1 的数据集采用基于预训练语言模型的内容推荐方法进行实验。用 BERT 模型得到图书嵌入表示，接着用余弦相似度计算出图书之间相似度，最后为读者推荐与其借阅图书相似的新图书。

2.1 问题定义

设 u 和 i 分别表示一个特定的读者和图书。与读者 u 借阅过的图书集记为 I_u^+，与图书 i 借阅的读者集记为 u_i^+。图书 i 的文本描述内容被记为 c_i。随机分配的表示图书 i 的单一序号被表示为图书的原子标识符 iad_i。除 iad_i 外，每个图书 i 还被分配一个生成标识符 $GID_i = [z_i^1, z_i^2, \cdots, z_i^l]$，其中 l 表示 GID_i 的长度。

生成式推荐任务给出描述 I_{U^+} 信息的输入，生成 GID 列表作为推荐结果。GID 是通过自回归方式生成的。向读者 u 推荐图书 i 的概率估计为：

$$p(u,i)=\prod_{t=1}^{l} p(z_i^t \mid z_i^1, z_i^2, \cdots, z_i^{t-1}, I_u^+) \quad (3\text{-}1)$$

推荐者选择排名最高的图书 N 作为读者 U 的推荐列表。

在本文中，主要面临两个推荐场景。第一个场景是对有行为数据（有读者和图书借阅记录）进行智能推荐，采用协同与内容信息融合增强的生成式推荐算法。第二个场景是对于刚入库的新书（没有图书相应的借阅记录），采用基于预训练语言模型的内容推荐方法。下文将分别介绍这两个场景所使用的推荐算法。

2.2 基于协同与内容信息融合增强的生成式推荐算法

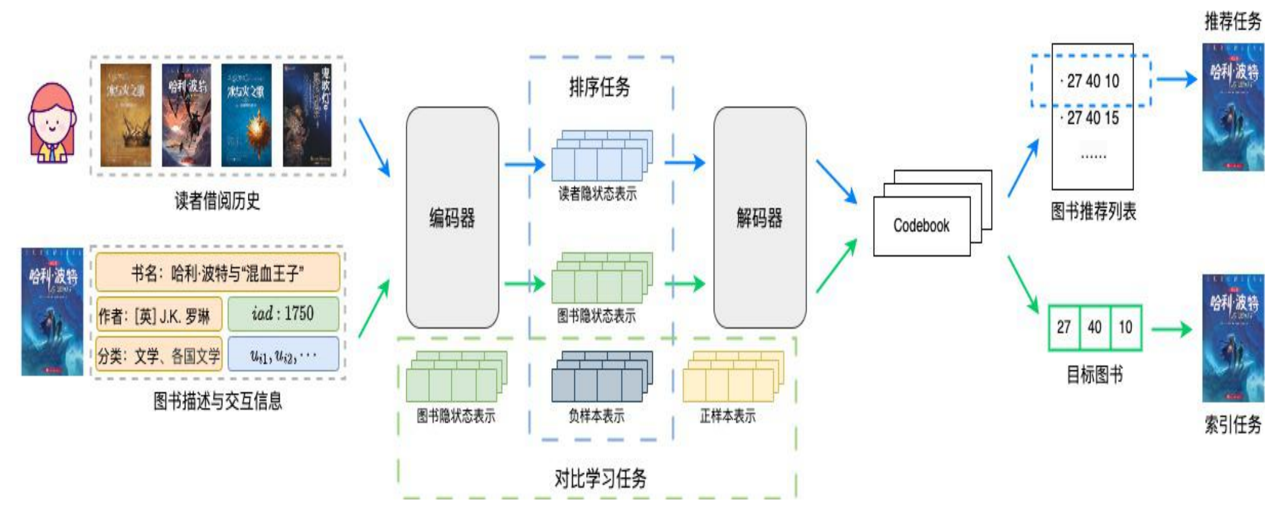


图 3-1 协同与内容信息融合增强的生成式推荐算法流程图

Fig3-1 The figure of collaborative and content information fusion enhanced generative recommendation algorithm recommend process

图 3-1 展示了所建议的协同与内容信息融合增强的生成式推荐算法是一个编码器-解码器架构的生成式推荐框架。能够同时考虑协同信号和图书内容信息，其中协同信号指的是读者和图书之间的借阅记录，图书内容信息即为图书的文本描述。具体来说，该算法首先使用基于图神经网络的协同过滤模型构建 GID。其次协同与内容信息融合增强的生成式推荐算法的训练包括两个任务:读者-图书推荐任务和图书-图书索引任务。读者-图书推荐任务的目的是将读者历史借阅图书的内容信息映射到推荐图书的 GID 中。图书-图书索引任务的目标是从图书侧信息到图书 GID 的映射。这两个任务都是通过一个基于共享编码器-解码器的语言模型来实现的，以更好地捕捉文本内容信息。为此，推荐任务将协同信号和图书内容信息统一起来以实现更好的推荐，而索引任务则执行协同信号和内容信息之间的对齐。需要强调的是，所涉及的语言模型的参数也进行了微调，以更好地适应语言模型进行推荐。

2.2.1 生成式标识符的构建

GID 的构建在生成式推荐中起着至关重要的作用，主要利用分层聚类方法从基于图神经网络的协同过滤模型构建 GID。具体来说，首先从经过借阅记录训练的 Light-GCN 模型中提取图书表示。然后采用有约束的 K-means 算法对图书表示进行分层聚类。当前层级聚类以上级聚类簇中的图书作为整个实例集进行。对于最后一层叶子节点，将序号 1 到 K 随机

分配给这些图书。这样，就建立了 K 叉树来组织图书集。每个图书都对应一个叶节点，而从根到叶节点的路径是该图书的 GID。由于 LightGCN 是在读者-图书借阅图上训练的，因此 GID 可以对协同信号进行建模。同时，GID 的每个位置都有一个码本嵌入矩阵来帮助将内容信息整合到图书的 GID 中。

2.2.2 读者-图书推荐

读者的输入为无序元组，每个元组描述该读者的一个借阅图书的内容信息。对于图书 i 的文本描述，采用通用数据格式。具体来说，图书 i 的文本描述 c_i 被表述为一个图书“句子”，它来自于一个由键值属性对 (k,v) 组成的扁平属性字典，iad_i 增加模型保真度。图书的内容描述为:

$$c_i = [iad_i, k_1 : v_1, k_2 : v_2, \cdots] \tag{3-1}$$

读者 u 的借阅项集记为 I_u^+.因此，读者-图书推荐任务的输入是：

$$X_u = [\{c_i \mid i \in I_u^+\}] \tag{3-2}$$

其后，采用一个基于编码器-解码器的模型来处理文本。$Encoder(X_u)$ 为隐藏状态。之后，给定在第 t 步步骤之前生成的标记 $z^{<t}$ 。这个过程可以表述为:

$$d_t = Decoder(Encoder(X_u), z^{<t}) \tag{3-3}$$

由 d_t 和位置 t 的码本嵌入矩阵 E_t 来计算步骤 t 的生成概率，表示为:

$$p(z^t \mid z^{<t}, X_u) = soft\max(d_t \bullet E_t^T), \tag{3-4}$$

对于训练集中的一对 (u,i)，推荐的生成损失公式为:

$$\iota_{rec} = -\sum_{t=1}^{l} \log p(z_i^t \mid X_u, z_i^1, z_i^2, \cdots, z_i^{t-1}) \tag{3-5}$$

在这项工作中使用预训练语言模型 MT5 作为生成式框架中所采用的模型。MT5 是由谷歌基于其 T5 模型开发的一个多语言模型版本，这个模型通过训练涵盖 101 种语言的数据集，具有显著的多语言处理能力。通过其跨语言理解能力、强大的性能表现、优化的数据集和训练方法以及广泛的应用前景等好处，为 NLP 领域带来革命性的变化。本文中 MT5 的参数通过反向传播进行微调，以更好地适应语言模型进行推荐。

在此基础上，进一步引入排序任务来增强其排序能力。此处随机采样一个读者 u 未曾借阅并且 GID 与正样本没有重叠的图书 i ，作为负样本 $i_$ 。利用 BPR 损失来优化排名，公式为:

$$\iota_{BPR} = -\ln \sigma(h(X_u) \bullet (h(X_i) - h(X_{i_}))) \tag{3-6}$$

2.2.3 图书-图书索引任务

为对齐协同信号和图书内容信息，引入图书-图书索引任务，将基于内容的语言空间映射到基于借阅的协同空间。图书索引任务的输入序列包含图书的文本信息。此外还引入与该图书借阅过的读者信息，以进一步编码协同信号。因此，索引任务的输入被表示为:

$$X_i = [c_i, \{uad_u \mid u \in \bigcup_i^+\}] \tag{3-7}$$

索引任务是通过与推荐任务相同的语言模型和码本嵌入进行的。索引任务的生成概率与 Eq.(4)和 Eq.(5)相似，只是模型输输入为 X_i 而不是 X_u。其后采用交叉熵损失进行参数调优。图书索引的损失定义为:

$$\iota_{index} = -\sum_{t=1}^{l} \log p(z_i^t \mid X_u, z_i^1, z_i^2, \cdots, z_i^{t-1}) \tag{3-8}$$

为了在协同信号和内容信息之间进行更为有效的对齐，进一步引入对比学习任务。其思想是具有相似 GID 的图书在基于内容的语言空间中也应该相似。为此，随机抽取一个在 GID 中子序列重叠的图书 i_+ 作为正样本，随机抽取另一个 GID 没有重叠的图书 $i_$ 作为负样本。对比学习任务损失被定义为:

$$\iota_c = -\ln \sigma(h(X_i) \bullet (h(X_{i_+}) - h(X_{i_}))) \tag{3-9}$$

其中 h(·)表示编码器(·)的最后隐藏状态，σ表示 sigmoid 函数。这样的对比损失有助于编码器学习更好的图书输入表示。

2.3 基于预训练语言模型的内容推荐方法

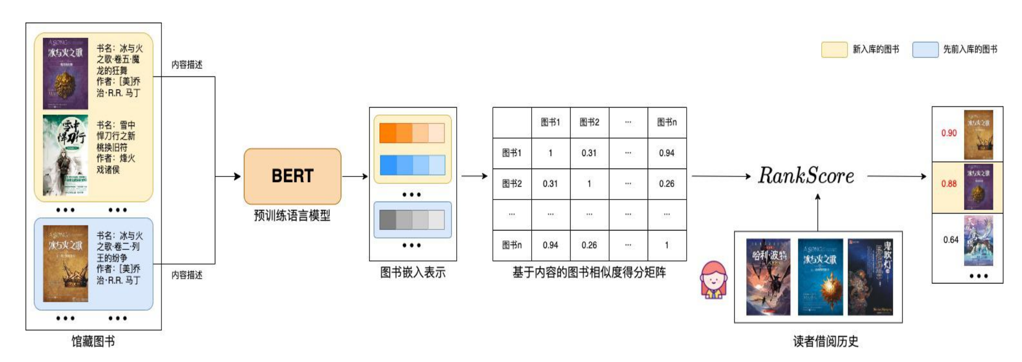


图 3-2 冷启动流程图

Fig3-2 The figure of cold boot recommend process

对于新入库的图书由于没有足够的读者和图书借阅记录，很难利用基于协同过滤的推荐模型来为读者推荐新图书。因此利用 BERT 预训练语言模型来进行新书的个性化推荐探索，为读者推荐与其曾经借阅过图书在内容上比较相似的新图书。

具体做法如图 3-2 所示。对于馆藏图书，根据图书的内容描述经过 BERT 预训练语言模型获得图书嵌入表示，其中的图书包括新入库的图书和有足够借阅记录的先入库图书。所用到的 BERT 模型是一种由 Google 在 2018 年提出的自然语言处理（Natural Language Processing，NLP）预训练模型。其中图书的内容描述包括书名、作者和图书分类类别信息。BERT 能给处理多语言数据，它的出现极大地推动了 NLP 的发展，可以应用于文本分类（如情感分析、主题分类）、命名实体识别、问答系统、文本摘要和机器阅读理解等多种领域，同时 BERT 在算法还有很大的优化空间。

其后，根据获得的图书嵌入表示采用余弦相似度获得基于内容的图书相似度得分矩阵。由于是根据相似度进行图书推荐，因而下一步更新读者对未借阅过图书的打分情况，利用根据图书之间相似度和读者对图书的借阅情况来联合预估该读者对某个未借阅图书的偏好情况。具体公式如下：

$$\hat{r}_{u,i} = \frac{\sum_{n\in N_{(u,i)}} S_{i,n} \bullet r_{u,n}}{\sum_{n\in N_{(u,i)}} S_{i,n}} \tag{3-10}$$

其中$S_{i,n}$是图书i和n之间相似度。$r_{u,n}$是读者 u 和图书 n 之间的借阅情况，读者有图书的借阅记录则该值为 1，否则为 0。最后根据图书的得分排序对读者进行未曾借阅图书推荐。

3 实验和结果分析/Experiment and result analysis

3.1 数据集

本研究选用山东大学图书馆 2017 年后采购的部分图书及其流通数据、读者信息来评估模型性能。其中包含图书信息 111479 条，读者信息 31840 条，借阅数据 390300 条。对于图书信息，选取元数据中的书名、作者、中图法分类号对应的分类类别作为图书的文本内容描述。

表 4-1 数据总数展示
Tab4-1 Data total presentation

	图书信息	读者信息	借阅数据
训练集	111479	31840	289000
验证集	111479	31840	48700
测试集	111479	31840	52600

表 4-1 展示了预处理后数据集的统计数据。根据读者和图书的借阅记录，将每个读者的历史借阅记录随机分成训练/验证/测试集，比例为 8:1:1，其中训练集包括借阅记录 289000 条，验证集含借阅记录 48700 条，测试集含借阅记录 52600 条。

表 4-2 基于预训练语言模型的内容推荐方法场景数据情况展示
Tab4-2 Content recommendation method scene data presentation based on pre-trained language model

	书目数量	书目占比
借阅次数=0	12330	11.06%
借阅次数<=1	59473	53.35%

如表 4-2 所示，基于预训练语言模型的内容推荐方法场景所用数据分为两类。训练集中未曾出现但测试集中出现过的图书数量为 12330，占比 11.06%。在训练集中借阅次数不超过一次的图书数量为 59473，占比 53.35%。

3.2 参数设置

本次实验中，使用 MT5-small 模型作为语言模型来构建。对于所有数据集，GID 的长度设置为 l=3，并将层次结构 K-means 中的簇数设置为 k=64。每个读者通过随机抽样的借阅图书元组的聚合来表示。使用均匀分布对负样本进行采样，避免不同负采样策略的影响。为了与预训练的 MT5-small 模型的词嵌入一致，本次实验中 uad、iad 和 codebook 的嵌入维数均设置为 512。对比任务损失权重设为 0.1。此外，利用 Pytorch 框架构建模型实现，使用 AdamW 优化模型，学习率为 5e-4，批量大小设置为 128，总共的训练轮数为 60 次。具体的实验参数和环境配置如表 4-2 和表 4-3 所示。首先进行 60 轮微调训练后把各轮模型保存下来，分别进行模型的验证，并选择指标最好的作为最终模型。

表 4-2 实验参数
Tab.4-2 Experimental parameters

参数名称	大小
学习率	5e-4
GID 长度	3
K-means 聚类簇数	64
对比任务损失权重	0.1
批量大小	128
训练总轮次	60

表 4-3 实验环境配置表
Tab.4-3 Experimental environment configuration table

参数名称	大小
GPU	GeForce GTX 3090GPU
处理器核心数量	48
内存容量	500G
服务系统	Linux
显存大小	24G
框架	Pytorch

3.3 基线模型

（1）MF：在推荐系统中将读者-图书评分矩阵分解为两个低维矩阵乘积，从而完成读者和图书的隐含特征提取及评分预测。

（2）LightGCN[28]：通过轻量级的图卷积神经网络，在读者-图书借阅矩阵上进行线性传播来学习读者和图书的嵌入，从而提取读者和图书的隐含特征，并利用这些特征进行推荐。

3.4 评价指标

本研究中，为精准评估基线模型与所提出模型的性能表现，选用以下两个经典的评估指标：

（1）召回率（Recall@N）

Recall@N 表示在前 N 个推荐结果中，模型检测到的正确目标的数量占所有实际目标数量的比例，以此评估模型在有限的预测结果中对正例的覆盖度。指标计算如公式（4-1）所示。

$$\text{Recall@N} = TP / (TP + FN) \tag{4-1}$$

其中 TP 表示真正例（True Positives），即模型正确预测为正类的实例数；FN 表示假反例（False Negatives），即模型错误地预测为负类的实际正类实例数。

（2）归一化折损累计增益（NDCG@N）

NDCG@N 在考虑各个图书位置的基础上，对各图书的相关性得分进行累加，并对处于较低位置的图书得分进行折损，以此评估推荐列表中各项的排名情况。指标计算如公式（4-2）所示。

$$NDCG@N = DCG@N / IDCG@N \quad (4\text{-}2)$$

其中DCG@N(折损累计增益)是根据推荐列表中前N个图书相关性和排名位置的对数计算得出的累计增益，IDCG(理想情况下的折损累计增益)是假设按照相关性降序排列计算得出的最大累计增益。

3.5 结果分析

表 4-4 借阅历史超过 1 的图书的表现

Tab4-4 The performance of books with a history of more than 1

	Recall@20	Recall@50	Recall@100	NDCG@20	NDCG@50	NDCG@100
MF	0.0067	0.0118	0.0185	0.0064	0.0084	0.0106
LightGCN	0.0077	0.0123	0.0206	0.0076	0.0092	0.0119
Content-based	0.0099	0.0161	0.0245	0.0090	0.0113	0.0139

如表 4-4 所示，对于借阅次数超过一次的图书推荐，相比 MF 和 LightGCN 方法，本文所用的基于协同与内容信息融合增强的生成式推荐算法在 Recall 和 NDCG 指标上都有明显提升，证实其有效性。

表 4-5 在不存在借阅历史的图书的表现

Tab4-5 The performance of a book with no interaction history

	Recall@20	Recall@50	Recall@100	NDCG@20	NDCG@50	NDCG@100
MF	0.0039	0.0051	0.0073	0.0015	0.0018	0.0023
LightGCN	0.0021	0.0048	0.0104	0.0009	0.0015	0.0026
Content-based	0.1056	0.1994	0.3053	0.0462	0.0677	0.088

如表 4-5 所示，对于不存在借阅历史的图书，相比 MF 和 LightGCN 方法，本文所用的基于预训练语言模型的内容推荐方法在 Recall 和 NDCG 指标上都有明显提升，证实其有效性。

表 4-6 借阅历史不超过 1 的图书的表现

Tab4-6 The performance of books with a history of less than 1

	Recall@20	Recall@50	Recall@100	NDCG@20	NDCG@50	NDCG@100
MF	0.0161	0.0207	0.0262	0.0097	0.0108	0.0119
LightGCN	0.018	0.0241	0.0323	0.0103	0.0117	0.0133
Content-based	0.0253	0.0644	0.1145	0.0117	0.021	0.0309

如表 4-6 所示，对于借阅历史不超过 1 的图书推荐，相比 MF 和 LightGCN 方法，本文所用的基于预训练语言模型的内容推荐方法在 Recall 和 NDCG 指标上都有明显提升，证实其有效性。

4 结语/conclusion

本文重点研究了统一内容特征及协同信息的生成式图书推荐方法框架。首先根据相关文献介绍图书推荐的重要性，了解生成式模型。本文主要针对两个场景分别进行研究，分别为借阅次数超过一次图书推荐和借阅次数不超过一次图书推荐。对于有图书借阅记录的图书，

使用协同与内容信息融合增强的生成式推荐算法，它是一个编码器-解码器架构的生成式推荐框架。首先利用 LightGCN 对图书进行特征提取得到嵌入表示，并获得其 GID。接着使用编码器-解码器结构整合图书内容描述信息对其进行端到端的图书推荐。对于借阅次数不超过一次图书则是利用基于预训练语言模型的内容推荐方法。用 BERT 预训练模型获取其嵌入表示，接着计算图书之前相似度，最后根据相似度为用户推荐与其曾经借阅图书较为相似的图书。

最后利用所处理的山东大学图书馆数据集进行相关方法实验。实验结果表明在两个场景中所采用的方法相对于 MF 和 LightGCN 算法无论是在 Recall 还是 NDCG 指标上都有明显提升，证实了其有效性。

参考文献/References：

[1] 吴若航,茆意宏.生成式人工智能变革图书馆阅读推广研究[J].图书与情报,2023(06):62-69.
[2] 张劲松. 基于用户生成文本的图书标签关联规则识别方法[J]. 情报杂志, 2021, 40(11): 182-189.
[3] 邹鼎杰,方世敏. 面向 OPAC 的非个性化图书推荐算法[J]. 现代情报, 2021, 41(02): 125-131.
[4] 陈俊鹏,虞为. 社会化标签环境下基于 J-WMF 的馆藏资源推荐[J]. 图书馆学研究, 2020, (21): 67-75, 93.
[5] 韩后,殷红岩,王冬青. 儿童数字阅读个性化推荐服务的设计与应用[J]. 现代教育技术, 2023, 33(12): 111-118.
[6] 吴彦文,刘雪纯,杜嘉薇,等. 融合微观行为特性的用户画像增强研究[J]. 情报科学, 2021, 39(03): 19-24, 50.
[7] 李晓敏,熊回香,杜瑾,等. 智慧图书馆中基于用户画像的图书推荐研究[J]. 情报科学, 2021, 39(07): 15-22.
[8] 王代琳,刘丽娜,刘美玲,等. 基于图书目录注意力机制的读者偏好分析与推荐模型研究[J]. 数据分析与知识发现, 2022, 6(09): 138-152.
[9] 黄禹,张文德,张诗雨. 基于深度距离分解的在线图书资源个性化推荐研究[J]. 情报科学, 2021, 39(03): 76-81.
[10] 熊回香,李晓敏,李跃艳. 基于图书评论属性挖掘的群组推荐研究[J]. 数据分析与知识发现, 2020, 4(Z1): 214-222.
[11] 成胤钟. 基于畅销书及意见领袖的图书推荐系统[J]. 计算机应用与软件, 2024, 41(01): 64-70, 104.
[12] 王井. 一种基于订阅记录的图书协同过滤推荐方法研究[J]. 情报科学, 2020, 38(03): 54-59, 77.
[13] 邹鼎杰,方世敏. 面向 OPAC 的非个性化图书推荐算法[J]. 现代情报, 2021, 41(02): 125-131.
[14] 韩后,殷红岩,王冬青. 儿童数字阅读个性化推荐服务的设计与应用[J]. 现代教育技术, 2023, 33(12): 111-118.
[15] 陈玲洪,潘晓华. 基于知识图谱和读者画像的图书推荐检索研究[J]. 数据分析与知识发现, 2023, : 1-16.
[16] 刘园园. 基于读者兴趣挖掘的深度学习推荐模型[J]. 西南大学学报(自然科学版), 2023, 45(04): 201-209.
[17] Yang Z, Wu J, Wang Z, et al. Generate What You Prefer: Reshaping Sequential Recommendation via Guided Diffusion[J]. Advances in Neural Information Processing Systems, 2024, 36.
[18]]Wenjie Wang;Xinyu Lin;Fuli Feng;Xiangnan He;Tat-Seng Chua.Generative Recommendation: Towards Next-generation Recommender Paradigm[J].2023,
[19] Guibing Guo, Huan Zhou, Bowei Chen, Zhirong Liu, Xiao Xu, Xu Chen, Zhenhua Dong, and Xiuqiang He. 2022. IPGAN: Generating Informative Item Pairs by Adversarial Sampling. IEEE Trans. Neural Networks Learn. Syst. 33, 2 (2022), 694 – 706.

[20] Zefeng Cai and Zerui Cai. 2022. PEV AE: A Hierarchical V AE for Personalized Explainable Recommendation. In SIGIR ’22: The 45th International ACM SIGIR Conference on Research and Development in Information Retrieval, Madrid, Spain, July 11 - 15, 2022, Enrique Amigó, Pablo Castells, Julio Gonzalo, Ben Carterette, J. Shane Culpepper, and Gabriella Kazai (Eds.). ACM, 692 – 702.
[21] Aleksandr V. Petrov and Craig Macdonald. 2023. Generative Sequential Recommendation with GPTRec. CoRR abs/2306.11114 (2023). https://doi.org/10.48550/ARXIV.2306.11114 arXiv:2306.11114
[22] Zihao Li, Aixin Sun, and Chenliang Li. 2023. DiffuRec: A Diffusion Model for Sequential Recommendation. arXiv preprint arXiv:2304.00686 (2023).
[23] Zeyu Cui, Jianxin Ma, Chang Zhou, Jingren Zhou, and Hongxia Yang. 2022. M6-Rec: Generative Pretrained Language Models are Open-Ended Recommender Systems. CoRR abs/2205.08084 (2022). https://doi.org/10.48550/ARXIV.2205.08084 arXiv:2205.08084
[24] Wang H, Zhang F, Zhao M, et al. Multi-task feature learning for knowledge graph enhanced recommendation[C]//The World Wide Web Conference. 2019: 2000-2010.
[25] 陈玲洪,潘晓华. 基于知识图谱和读者画像的图书推荐研究[J]. 数据分析与知识发现, 2023, 7(12): 164-171.
[26] 黄禹,张文德,张诗雨. 基于深度距离分解的在线图书资源个性化推荐研究[J]. 情报科学, 2021, 39(03): 76-81.
[27] 丁永刚,张雨琴,付强,等. 基于 SOM 神经网络和排序因子分解机的图书资源精准推荐[J]. 情报理论与实践, 2019, 42(09): 133-138, 170.
[28] Xiangnan He, Kuan Deng, Xiang Wang, Yan Li, Yongdong Zhang, and Meng Wang. 2020. Lightgcn: Simplifying and powering graph convolution network for recommendation. In Proceedings of the 43rd International ACM SIGIR conference on research and development in Information Retrieval. 639 – 648.

Research on Content based Generative Book Collaborative Recommendation Method

Cheng Chuansheng[1] Xin Xin[2] Wang Yidan[2] Li Xiaojie[1]
1.Shandong University Library, Jinan 266000
2.School of Computer Science and Technology, Shandong University, Qingdao 250101

Abstract: [Objective] To alleviate the problem of information overload in book resources and enrich readers' online experience through generative book recommendation methods. [Application Background] Applied to the book recommendation service of Shandong University Library, covering 111479 pieces of book information purchased after 2017, 31840 pieces of related reader information, and 390300 borrowing records. [Method] For book recommendations with borrowing times greater than 1, a generative recommendation algorithm enhanced by the fusion of

collaborative information and content feature information is adopted. For book recommendations with borrowing times less than or equal 1, a content recommendation method based on pre trained language models is adopted to solve the cold start problem. [Result] The experimental results show that for books borrowed more than once, compared to the LightGCN algorithm, the method proposed in this paper Recall@100 The improvement has reached 18.9%, NDCG@100 The improvement has reached 16.8%; For books without borrowing history, compared to the LightGCN algorithm, the method proposed in this paper Recall@100 Reaching 0.3053, NDCG@100 Reached 0.088; For books with a borrowing frequency of no more than 1, compared to the LightGCN algorithm, the method proposed in this paper is Recall@100 Reaching 0.0145, NDCG@100 Increased by 132%. [Conclusion] The generative book recommendation method that unifies content features and collaborative information has superior performance and can play an important role in reducing information overload and enriching readers' online experience.

Keywords: Book recommendation; Generative model; Collaborative filtering

* This work is supported by Key Project of Education and Teaching Reform Research at Shandong University titled "Future learning ecosystem construction in the era of digital intelligence" (Grant No. 2023Z21).

Authors: Cheng Chuansheng, Deputy Director of the Library, Deputy Research Librarian, postgraduate; Xin Xin, lecturer, PhD; Wang Yidan, graduate student; Li Xiaojie, Director of the Network Information Technology Center, librarian, postgraduate, E-mail:lixiaojie@sdu.edu.cn, The corresponding author.